04 | 爬虫基础理论概述：如何低调地拿到自己想要的数据？

2022-01-26 DS Hunter

《反爬虫兵法演绎20讲》 课程介绍 >

讲述：DS Hunter

时长 22:44 大小 31.24M

你好啊，我是 DS Hunter。又见面了。

前面我和你聊了聊爬虫和反爬虫的历史，感觉这是一个内卷的死结。

在开篇词里我提到过：内卷之下无胜者。也就是内卷一旦开始，你就只有两个结局：输，或者输得很惨。你的所有努力，都是让自己不要输得太惨，而不是考虑如何创造收益。有了这个基本方针之后，我们才能知道后续应该往哪个方向去努力，才好进一步制定对应的策略。

通过第一个模块的历史视角回顾，相信你已经对什么是爬虫有了更深刻的了解。而从这一讲开始，我们就正式进入爬虫、反爬虫的理论环节。接下来所有的讨论，就从发起攻势的爬虫方开始吧。

从“5W1H 分析法”到爬虫行动

我首先要问你一个问题：老板把任务给你了之后，爬虫要干什么？

根据 5W1H 原则（万恶的方法论啊），你可以看到，需要讨论的有：WHAT、WHERE、WHEN、WHO、WHY、HOW。那么迁移到爬虫身上呢？

老板把任务布置下来之后，这个 WHO 就没什么可讨论的了，肯定是你，爱干不干，不干走人。 至于 WHY？老板有需求，有什么可 WHY 的，还是不干就走人。而 WHERE，WHEN？当然是 Anywhere，Anytime，卷起来！只要对方站点扛得住，就日以继夜地死命干他。后面在 06 讨论分布式的时候，我会和你分享分享关于 WHERE 和 WHEN 的思考。

现在，我们就只剩下了 WHAT 和 HOW。这也就简单了很多。我们的问题只有：爬什么，怎么爬？所以，接下来我会带你了解爬虫的抓取流程。在这个过程中，你就能理解怎么在完成老板需求的同时，保护好自己。而整个过程的关键词只有一个，那就是“低调”。

抓取流程

爬虫随着网络而生，那么我们讨论的爬虫要么基于 TCP 协议，要么基于 HTTP 相关的协议。也许有些爬虫是爬 FTP 的，但是这种情况非常少。当然，不管使用什么技术，我们都要始终记住一点：**保持低调。**毕竟爬虫本身就不是一个光明正大的事情，再高调地去抓取自己想要的东西，就会死得很快。

既然确定了技术方向，那么接下来，就要进行抓取了。根据大多数爬虫系统的经验来看，无论是什么爬虫，我们主要的抓取步骤都是以下四个部分：

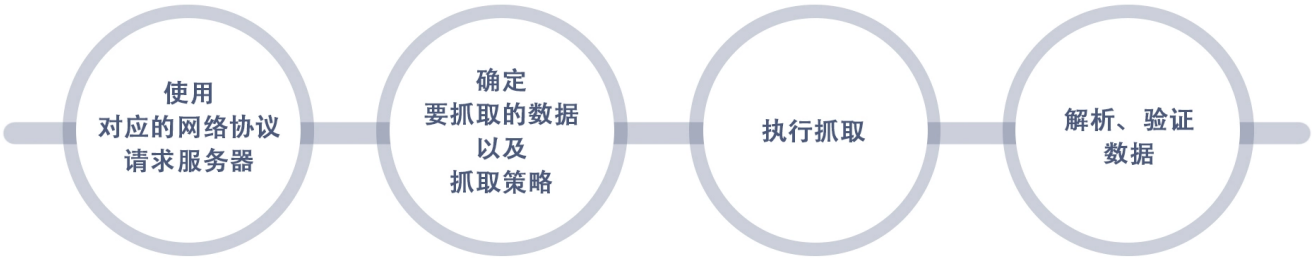

抓取流程图

其中，最能帮助我们保持低调的就是步骤二和步骤三了。而至于步骤一和步骤四，我会详细地跟你说说和提升能力、降低消耗有关的事情，也会对你有不小的帮助。我们就从第一步开始吧。

使用对应的网络协议请求服务器

关于使用对应的网络协议请求服务器，简单来说，就是对方用什么我们就用什么，而 Web 一定是 HTTP，App 大部分是 TCP。这一句话就可以解释第一步的动作方向了。

今天这一讲，我们**主要讨论使用 HTTP 协议请求服务器的情况。**不要觉得武断，我们还是从历史的角度来进行说明。

我们都知道，在本质上，爬虫就是一个 Cosplay。服务器开放了端口给浏览器访问，那么就必然无法验证来访问的是不是一个真的浏览器。

最早我们是使用 TCP 协议直接发起请求的，写爬虫的人需要创建一个 TCP 链接，按照 HTTP 协议的格式逐字节去写入数据，分析返回数据，来实现数据的抓取。

谢天谢地，这种残酷的日子一去不复返了。现在各大语言都直接加入了 HTTP 请求相关的库，甚至随着爬虫的发展，很多爬虫专用的库也出现了，越做越精细，也越来越不需要你关注底层了。

目前来看，**大多数情况下，我们抓取服务器都是用 HTTP 协议**，毕竟爬虫是随着 Web 2.0 发展起来的，而 Web 2.0 的主要载体就是 HTTP。

你可能会觉得，随着 App 时代的到来，HTTP 越来越不吃香，反而是 TCP 的爬虫又追了上来。但我要说的是，虽然现在各大公司的信息主要以 App 为主了，不过 HTTP 爬虫也并非一无是处，首先它可以快速抓取，其次它可以用来辅助验证 App 的抓取结果。因此 HTTP 爬虫会长期存在，不会消失，这也就是我们主要讨论 HTTP 协议请求服务器的原因。

所以，虽然有些 HTTP 的技巧会慢慢变得不实用，但只要大家没有抛弃 Web，HTTP 爬虫就一直有用武之地。

除此之外，关于这里的能力提升，我的建议是：

去撸一个 TCP 爬虫。

> 为什么又到了 TCP 爬虫？
>
> 原因很简单，爬虫，这个过度封装的 Cosplay 爱好者，它过度封装之后的好处就是无需关注细节。但是坏处也就是一旦细节出了问题，你根本不知道问题出在哪里。像是 03 中反向注入的故事，就是在封装好的爬虫的内部动了手脚。因此，直接用底层 TCP 撸一个线上爬虫用于生产，我是绝对不赞成的，这属于炫技，毫无用处。但是作为入门，这种练习对细节的考察还是很深入的。后续如果碰到高阶反爬虫，在底层原理上下绊，也能处理得游刃有余。
>
> 此外，如果你后续要进阶到 App 爬虫，大部分是要回到 TCP 层来抓取的，因为基本上没有哪家 App 还在使用 HTTP 协议了，都是自有的定制协议。这类协议要用 TCP 抓包，然后猜测每个字节的用处。

确定抓取数据及抓取策略

确定对应的网络协议请求服务器之后，我们就可以着手准备挑选抓取对象了。

为了后续能够顺利讨论，我们先来明确一下各个名词的含义。

抓取数据部分，我们通常会将商品数据分为两类，**重点商品**和**热卖商品**。重点商品，可能是我们后续需要观察的商品；热卖商品，则是用户关心的、经常点击的商品。当然，两者可能有重叠。

至于**抓取数据的手段**，从抓取的时机维度，我们通常将抓取手段分为两类，一类是 **Job 抓取**，一类是**实时抓取**，这两种手段各有优劣。Job 类型的抓取，周期性很强，在流量曲线中容易被抓；实时抓取相对来讲不易被抓，但是因为是通过用户点击商品实时触发，所以我方的热卖产品信息，很容易泄露。我们能做的，就是利用它们的优劣来决定我们要抓取的数据和抓取策略。

好了，所有的概念明确之后，我们来看看抓取数据和抓取策略的选定吧。这一步，是我们整个抓取流程的重点之一。想要低调，就要先收一收自己的野心。

毕竟你的老板一定会说：我全都要！但是这并不现实。

不现实的第一个因素：**流量问题**。要知道，你们是竞对，假设你们各占 50% 的市场份额，这就意味着如果你有 N 个商品，那对方也有 N 个商品。你的 N 个商品要和对方的信息来对比，那么你至少抓取量是 N。如果价格实时变化，每天需要抓取 k 次，那么抓取量就是 kN。再假设你的每日 PV（Page View，页面浏览量）数是 M，那么每个用户在查询价格的时候，你们会触发一个实时比价爬虫，那么对方就会收到 M 的爬虫流量。这样算下来，对方一共要接受 M+kN 的流量。

而他是你竞对，你们的 PV 是 M，他的 PV 十有八九也是这个级别的。这意味着他系统承受的爬虫流量要超过自己业务流量。你如果还奢望在这种情况下隐藏自己，实在是太不现实了。

所以，一定要和老板砍掉“我全都要”这种需求！再次强调，**要低调！**

第二个因素：**爬虫的危险性**。实时爬虫一旦触发，竞对如果借着你的爬虫顺藤摸瓜，记录下来你的热卖产品，然后进行分析，那才是最可怕的。况且，能立刻得到你的销售数据，这一点可比反爬虫本身更有价值。因此，实时爬虫一定不要做！非做不可的话，一定要做随机，不能全量实时抓取，否则，全量实时抓取就等于对方本来不知道你这面的销售数据，结果你主动推送数据给对方。

通过咱们刚刚聊到的两个点，我们可以知道，圈定重点商品之后，再加上部分随机热卖产品，就是我们要抓取的数据了。而我们的抓取策略就是：**重点商品数据用 Job 抓取，热卖商品数据用实时爬虫抓取。**

最后，还是要和你强调一下，确定数据是爬虫的一个重点，绝对不能随意圈定。尤其是不能让产品经理随意定，屁股决定脑袋，产品经理的职位注定了他们需要尽可能多的数据，如果你问他们一个数据需要不需要，那答案一定是需要。

他们完全不懂爬虫的可怕之处，也不了解反爬虫的阴险之处，即使了解，他们也可能为了自己的业绩，假装不知道。一定要有专业的人来决定这个事情。或者，增设一个爬虫产品经理的岗位，他可以不仅仅对“数据全面”这一个指标负责，也综合考虑公司利益。产品经理并非坏人，KPI 才是万恶之源。

执行抓取

确定了网络协议、抓取的数据和抓取策略之后，就可以开始执行抓取了。根据第 2 步我们知道，现在需要抓取的数据被分成了两部分，一部分是重点商品，一部分是热卖商品。我们先来看重点商品部分应该怎么执行抓取。

重点商品：Job 抓取

重点商品是走 Job 的，因此，需要定期触发。Job 不要过于频繁，否则就无法低调的抓取。

此外这里有个误区，很多人为了避免对方服务器被抓出问题，就赶在业务低谷期（错过业务高峰）去抓取，这可就大错特错了！

国内业务低谷期一般在凌晨三、四点左右，这个时候，服务器压力的确小了很多。但是你要考虑对方的程序员也都下班了，一旦出了问题，没有人能快速上线解决，只能靠值班的人先壮士断腕——降级熔断，然后再联系对方的程序员。你的本意可能是想对竞争对手好一点、保留一些善意，可是发生这样的事情，是不是与你的预期完全不一样呢？

而高峰期，虽然服务器压力较大，但是要注意，对方的人是齐全的，不管发生什么事情都可以迅速搞定，甚至秒级扩容，这个时候抓取出问题的概率比低谷期还更低一些。这个与我们的直觉可能完全不同。

此外，很多商品可能价格是随时变动的，你大半夜抓个价格，到了白天的时候还有什么参考价值呢？

因此，**Job 正常设置，不用刻意挑时间，唯一需要注意的是频率。**此外，**Job 开始，并不意味着抓取开始，Job 应该只是将抓取消息发送给节点，具体的抓取时间应该由节点自己来决定。**简单的说就是：将在外，君命有所不受。

最终节点再将信息汇总，抓取就结束了。这就是 Job 类型的抓取。

热卖商品：实时爬虫

刚刚提到还有一种抓取就是实时爬虫。这里要注意两点，一个是**数据范围**，另一个就是**具体抓取习惯**。

首先，数据范围，也就是商品选择。实时爬虫的范围要尽可能小，并且不能全是热卖商品，一定要再加入一些非关键商品。尽可能将部分头部商品加入池，部分中部产品加入池，然后每天轮换，头部商品和中部商品的比例也要一直调整。

虽然这样会带来业务的一些不满——毕竟他们期待的理想结果是全爬。但是为了保护公司隐私，这是不得不做的策略——并且要尽可能**保密**。要知道，商场没有太大的秘密可言，如果你信任你的同事，把策略都告诉他了，可能你就是酒足饭饱吹个牛而已。但是下个月，他也许就会跳槽到了竞对。到时候他还会保密吗？

第二点，具体抓取的习惯，一定要是和 Job 爬虫不一样的。为什么要注意这些问题呢？其实主要是**怕被对方反抓**。

我们刚刚说过，Job 爬虫是非常容易被对方抓的，如果对方抓了之后不拦截你，假装没抓到，就可以根据你的请求特征，顺藤摸瓜抓你的实时爬虫，后果会很恐怖。实时爬虫通常意味着这些商品对你最重要，那么未来在商业上，他们会重点打击这些商品。

如果针对 Job 爬虫和实时爬虫使用不同的抓取代码，能大大降低这个概率，因为看起来像两拨人，很难串联起来。这样，也就做到了低调。不过因为人的惰性，一般即使用了两套代码，也不会相差特别大，会有相同的个人习惯在里面。

理想的状况，是有足够的资源支持，两个团队互不交流、分别抓取。不过这样的成本实在不低，至少代码库要用两套。但是这样的好处就是，对方即使抓到你了，也会质疑自己的判断，认为不可能是同一拨爬虫。

解析、验证数据

拿到了数据却无法快速解析、无法验证真伪，其实就相当于拿到了没用的数据，那接下来我们就一起帮助数据发挥自己的价值。

解析数据

解析数据是个千古难题。

这里推荐一篇叫《火星人的耳机》的文章给大家。虽然是一篇很老的文章，但是他详细解释了为什么 Web 标准这么难做，HTML 标签那么混乱。

简单来说，就是因为浏览器版本的更新迭代，要持续保持兼容性，因此 HTML 的解析就变得逐渐混乱起来。遵循标准本身没有商业利益，浏览器厂商动力也不大。加上标准诞生于浏览器之后，不可能让前置的浏览器穿越时空来遵循后制定的标准，这就好比我们不能要求古装剧的人像现在的人去思考，他们有他们那个时代的思考逻辑。

这一点， 直接导致了解析 HTML 一直以来占据了爬虫的大部分工作量。

谢天谢地，现在有很多库可以支持帮你解析，不用自己来写正则一个一个匹配了。但是碰到畸形的标签，还是要手动调整——甚至对方可能是故意的！很多反爬虫方对一些畸形的 HTML 标签了如指掌，并且他们知道浏览器可以解析：因为他们可以通过线上用户帮自己去测试。这也就是我们解析数据的第一个方法，**库的支撑和手动调整相结合**。一般说来，这样就不至于自己写正则了。

除此之外， 我们还有一个方法就是**走浏览器渲染直接拿到 DOM**（Document Object Model，文档对象模型）。这种办法原理上没有任何问题，唯一的死穴就是，性能太慢了。DOM 渲染是前端一大难题。大部分前段框架，核心的功能就是在减少 DOM 操作，提高浏览器性能。因此本地拉浏览器引擎进行渲染，并非不能做，但是你需要极大的资源，需要评估是否值得。

总体表现如下表：

	机器资源消耗	人力资源消耗
手动解析HTML	低	高
浏览器解析DOM	高	低

手动解析HTML和浏览器解析DOM的消耗情况是相反的。

极客时间

手动解析HTML与浏览器解析DOM的对比

我们说过，一旦一个技术问题成为一个 ROI 问题，那么反倒好办了。你只需要在收益上打平消耗即可。因此，我们现在需要考虑的问题是：我们在解析数据上大概能付出的成本有多少？

从表格中可以看出，浏览器直接解析 DOM 会导致机器消耗高，而手动解析 HTML 会导致人力资源消耗高。但我们根据常识可以知道，机器成本是线性的，而人力资源消耗是一次性的，或者认为是边际递减的。所以，如果你的解析量并不大，那么可以考虑用浏览器解析来降低总成本，让机器消耗去吧。而如果解析量很大，那么尽可能使用代码来解析，是时候消耗人力资源了，这样能够获得一个高效率的解析，降低总成本。

验证数据

最后是验证数据，也就是验证你抓取到的数据是不是真实数据。

验证数据有两种，一种是机器验证，一种是人工验证。机器验证在前面我们已经详细介绍过了，还介绍过反爬虫方的反验证方式。因此打到最后，难免会进入人工验证。这里，你也可以参考在02中的机器人工双校验部分，具体的步骤内容非常详细。今天，我们重点来看看这两种验证方式的注意事项。

首先是**机器验证**。

机器验证一般就是交叉验证，也就是 PC 端、小程序等等各个渠道互相校验。但是，这样做会增大对方服务器的压力，会有被发现的风险，因此不是很推荐。

此外机器验证还有一种取巧的办法就是，有意中个爬虫试试，看下对方提价数值是多少。如果你的爬虫也拿到了这个价格， 那就说明你的机器验证策略被发现了。当然，这种办法只能针对那些提价策略并不复杂的反爬虫团队。不过总的来说，还是一个很好的补充手段。

而**人工验证，则没有任何技术含量，基本就是人工抽检即可。当然，也有一些需要注意**的事情。

第一，人工验证不再有小概率性事件的概念。你需要时刻记住：你面对的是活生生的人，而不是自然界的随机事件。一旦你的爬虫中了，那就是中了，人工干预的事件，是不符合概率论的。直接丢弃全部数据即可，它们没有一个是可信的。至于何时重试， 需要根据成本来综合考虑。

第二，要熟知对方的业务逻辑，知道价格计算方式，避免因为不了解对方的价格计算模式而误以为自己价格抓错了。例如有些价格与优惠券、地区、用户属性相关等等。如果你不了解，拉到不同的价格就以为自己做错了，将寸步难行。因此验证数据这一步，建议对业务熟悉的人员来操作，而不是通用的测试人员。

基于这一点，我一直反对把爬虫做成中台。中台看起来节约了研发成本，但是天花板实在是太低了。有些公司，前期还能做得有模有样，但是，一旦对方发力做反爬，就无法招架。这就是因为中台方对对方的业务了解程度不高，被欺骗了都不知道。

再看另一个例子，有个公司抓取别人的小说，一直以为自己抓得好好的，实际上都是对方拿别的章节来冒充的。在没有业务端和读者反馈的情况下，技术人员很难发现这一点，甚至还觉得自己特别厉害。

总结

好了，到这里，我就介绍完了低调完成爬虫操作的全过程，给你总结一下吧。

首先，我们会使用对应的网络协议请求服务器，这里根据对方服务器使用的协议，我们就可以直接确定我们需要使用的协议。接下来是确定要抓取的数据并且制定抓取策略，这里

也是整个工程的重中之重，能不能实现低调就看这个策略了。我们能做的，就是挑选出重点需要关注的商品，舍弃一部分并不重要的商品，甚至为了隐藏自己的商业数据，可以有意减去一些重点商品，避免因小失大。

然后，就是执行抓取了。这里需要注意的是，实时爬虫并不推荐，非做不可的话，一定要注意，把**低调**刻在自己的骨子里。尤其是数据集上面，一定要敢于舍去部分重点商品，壮士断腕，避免被对方反向分析，得不偿失。

最后，是数据的解析和验证。解析这里，我为你提供了两种解析方式以及它们的选择方法。记住，只要比对方消耗得少，你就胜利了。而验证的时候，我提到了可以通过有意被抓来验证数据，减小对方服务器的压力来保持低调。

要知道，**低调不低调，不是给机器看的，是给对面的人看的。**只要对面的人没发现你，那么你就低调成功了。

那么，足够低调的情况下，就能一直抓取了吗？答案是否定的，毕竟这是一个又卖矛又卖盾的课程。下节课，我们就从反爬虫的视角再看看，如何应对爬虫方低调的抓取。

思考题

最后，又到了愉快的思考题时间。还是老规矩，三选一，记得保密脱敏啊：

1. 假设你想实现低调的抓取，最多只能支持 100QPS。但是要完成老板的需求，最少也要 1000QPS。那么，如何解决这个问题？另外，在你眼里，100 和 1000 的 QPS，分别是一个什么样的量级？
2. 假设在解析数据的时候，你发现每次解析都会引发一个埋点发送到服务端，证明自己解析成功了。那么，这个埋点你会模拟发送吗？是不发送显得低调，还是同步发送更低调？
3. 如果有畸形的 HTML 标签要解析，不同浏览器解析方式不一样，你会在 user-agent 节点锁死浏览器版本吗？

期待你在评论区的分享，我会及时回复。反爬无定式，我们一起探索。

极客时间

出行必备隐身术，工作常带指南针。

反爬虫兵法演绎 20 讲

DS Hunter / 反爬虫专家，前某公司研发总监

识别二维码
免费试读

分享给需要的人，Ta订阅超级会员，你将得 50 元

Ta单独购买本课程，你将得 20 元

生成海报并分享

赞 1 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 春节加餐03 | 低调驶得万年船

下一篇 05 | 反爬虫的应对之策：通用且基本的检测规则是什么？

精选留言 (5)

写留言

程序员二师兄
2022-01-26

第一个问题：
100qps: 百万级pv
1000qps: 千万级pv

第二个问题：...
展开

作者回复: 赞，看来是有经验的。

3

peter
2022-01-26

请教老师三个问题：
Q1：安卓APP不用HTTP吗？
本篇中有这样两句话：
1、“关于使用对应的网络协议请求服务器,Web 一定是 HTTP，App 大部分是 TCP”。
2、“因为基本上没有哪家 App 还在使用 HTTP 协议了，都是自有的定制协议。这类协议...
展开

作者回复: 这个是这样的，由于tcp的高效，所以大规模下一般会用tcp，当然初期也可以用http，最后一般会转成 tcp的。当然本课也不讲app爬虫所以就带一下，说明下tcp也是有用的。
Q2，http是基于tcp的，所以写http就是写tcp，只是库帮你做掉了。想自己撸tcp，理论上也是没问题的。
Q3，实时抓取指的是，用户在你站点点击了某商品，触发一个爬虫，去竞对看下对应商品。因为是用户触发的，这样，他就知道你这面用户在点哪些商品。这个信息是非常有用的。

共 2 条评论 >

webmin

2022-01-26

1. 100QPS单机可能就能搞定，但是到了1000QPS就要上集群或者流水线多机协同了；
2. 如果是单机搞定整个流程那么可以发送，如果是要抓取和解析是不同的机器，那么选择不发送，如果要让解析机去发送一可能时间已经晚了利用时间差信息也能看出问题，二是要用同样的IP回去访问好像不利于代理池的使用；
3. 前面的同学回答的已经很好，只是补充一点浏览器的版本可以使用一些公开的版本统...

展开

作者回复: 基本差不多，补充一下，不止可以用公开的版本数据，也可以用自己网站的统计数据，更准确。

共 2 条评论 > 1

leslie

2022-01-26

第一个问题：是量上的取舍；第二个问题：我会选择低调；第三个问题：锁死版本不合适现状，虽然不少开发习惯性锁死版本甚至浏览器。

leslie

2022-01-26

第一个问题：是量上的取舍；第二个问题：我会选择低调；第三个问题：锁死版本不合适现状，虽然不少开发习惯性锁死版本甚至浏览器。

共 1 条评论 >